

基于风险约束的智能投资组合优化

李维维

贵州大学经济学院, 贵州 贵阳

收稿日期: 2024年9月11日; 录用日期: 2024年10月16日; 发布日期: 2024年11月7日

摘要

智能投资组合优化旨在通过有效的资产配置来最大化投资回报, 同时控制风险。本文研究了基于风险约束的智能投资组合优化策略, 比较了遗传算法、模拟退火算法、粒子群算法和蚁群算法在实际市场数据中的应用。实验结果表明, 蚁群算法在处理复杂投资组合优化问题时表现出色, 尤其在高波动市场中。基于不同市场条件和投资者需求的比较分析, 本文提供了优化选择建议, 以提升投资组合管理效率。这一研究不仅丰富了智能投资组合优化的理论基础, 还为实际投资决策提供了实用的指导。

关键词

投资组合优化, 风险约束, 智能算法

Intelligent Portfolio Optimization Based on Risk Constraints

Weiwei Li

School of Economics, Guizhou University, Guiyang Guizhou

Received: Sep. 11th, 2024; accepted: Oct. 16th, 2024; published: Nov. 7th, 2024

Abstract

Intelligent portfolio optimization aims to maximize investment returns through effective asset allocation while controlling risks. This paper investigates risk-constrained intelligent portfolio optimization strategies, comparing the applications of genetic algorithms, simulated annealing algorithms, particle swarm algorithms, and ant colony algorithms using actual market data. Experimental results demonstrate that the ant colony algorithm excels in handling complex portfolio optimization problems, particularly in high-volatility markets. Based on a comparative analysis of different market conditions and investor needs, this paper provides optimization recommendations to enhance portfolio management efficiency. This research not only enriches the theoretical

foundation of intelligent portfolio optimization but also offers practical guidance for actual investment decision-making.

Keywords

Portfolio Optimization, Risk Constraints, Intelligent Algorithm

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在当今全球化与数字化迅速发展的经济环境中，投资组合管理面临着前所未有的挑战和机遇。全球投资管理领域正受到复杂多变的宏观经济环境和地缘政治风险的影响，包括金融市场的动态变化、科技革命对投资方式的冲击、投资者对新兴策略的多样化需求，以及金融市场监管的不断调整。这些因素共同推动投资管理者不断探索创新的投资组合优化方法，以适应快速变化的市场环境和投资者的多样化需求。长期以来，投资组合优化依赖于传统理论框架，如现代投资组合理论(MPT)和资本资产定价模型(CAPM)。尽管马科维茨的均值方差模型得到了广泛应用，但它未能充分考虑市场的复杂性和多样化风险因素，导致在实际操作中表现欠佳。随着市场环境的变化和投资者偏好的多样化，对更精确且全面考虑多种风险因素的投资组合优化方法的需求日益增加。智能投资组合优化结合机器学习和优化算法，旨在通过处理大规模数据和复杂模型，实现投资组合的最优配置，从而达到更好的风险收益平衡。这种方法不仅关注收益最大化，还强调有效控制风险，尤其在不稳定的市场环境中。相比传统方法，智能化方法能够更灵活地适应市场变化，提供更精准的投资决策支持。

尽管已有大量研究集中于投资组合优化和市场趋势预测，但结合风险约束条件，探索和应用智能算法的研究仍显不足。风险约束是投资决策中不可或缺的一部分，直接影响投资组合的构建与资产配置，旨在平衡预期收益与承担的风险。因此，本文旨在探讨如何在现代投资理论的基础上，将智能算法与传统投资管理理论及严格的风险约束条件相结合，以优化投资组合的构建和管理，解决传统方法在风险管理方面的局限性。在这方面，本文的创新性体现在多个层面。首先，本研究首次系统性地探讨了如何将先进的智能算法与风险约束条件整合，以实现更精准的投资组合优化。通过结合遗传算法、粒子群算法等智能优化技术与风险控制机制，本文将展示如何在实际操作中有效平衡收益与风险。此外，本文还将通过实证分析，展示不同智能算法在投资组合优化中的应用效果与实际成效，填补现有文献中对智能算法实际应用效果的空白。同时，研究将通过理论与实践的结合，为投资者和资产管理公司提供可行的工具和方法，以应对金融市场日益复杂的挑战。这样的应用导向研究将为业界提供切实可行的解决方案，助力金融市场的可持续发展。

2. 文献综述

随着实际问题中涌现出的大规模或超大规模优化现象，经典优化算法在越来越多的情况下无法在可接受的时间约束下获得令人满意的解。随着智能时代的到来和对财务数据分析的需求不断增长，通过使用计算机进行大量计算，以此达到投资组合管理最优化已经成为了一种可能，不少学者开始探索人工智能是否能够达到优化目标，事实证明，人工智能算法可以比传统统计学模型能更好地处理非线性和非平稳特征[1]。

智能优化算法源于 20 世纪 80 年代末, 到目前为止, 关于智能投资组合优化的研究中, 国内外大多数学者采用传统的机器学习对所取研究数据进行分类汇总, 然后构建相对应的模型, 从而为投资者选择一个更合理的投资组合, 其中应用到的方法主要包括: 专家系统[2]、支持向量机[3]、进化算法[4]、梯度下降[5]、人工神经网络[6]等, 目前, 许多学者已经应用这些算法来解决投资组合这一问题的优化, 并进行了相应的对比分析。

薛雨石在平均方差投资组合模型中利用了回报和风险之间平衡的想法, 以 0-1 背包问题为媒介, 并使用 MATLAB 程序实现遗传算法, 一种智能优化算法, 因此模型的解决方案过程具有生物遗传进化能力和适应能力, 并最终获得了具有最大回报的投资组合[7]。周新和赵明君以上海证券交易所所有 A 股主板股票为研究样本, 以相应市场的指数每周回报率为目标指标进行示范, 使用遗传算法解决优化设计, 并详细描述了染色体的设计、目标函数的设置及其在投资分析中的作用[8]。在总结和归纳收集到的原始数据后, 陈霞分别采用微分算法和遗传算法进行优化, 同时保持合并收入不变, 结果表明, 微分演化算法更适合她论文中讨论的投资模型[9]。张波等将粒子群优化算法应用于基于 VaR 的投资组合模型, 根据在上海证券交易所获取的实际数据进行了计算机仿真, 结果表明该算法得到的最优投资组合是实用有效的[10]。吴昊等认为, 传统的粒子群优化算法存在单种群问题, 很容易落入局部最优解决方案。为了提高样本群的多样性, 避免落入局部最优解决方案, 他们提出了一种基于改进的粒子群优化算法的改进的粒子群优化算法[11]。于延磊选择了上海和深圳股市的五只股票, 玉宝作为研究对象, 改进了蚁群算法, 成功将其应用于投资组合模型的优化, 并进行了实证研究。在经济学范围内对实证结果进行了分析, 分析表明, 模型获得的结果与现实一致[12]。

基于风险约束的智能投资组合优化研究相对较少, 目前发现的相关研究主要有两项。首先, 王舞宁基于强化学习, 提出了一种考虑风险因素的动态交易智能投资组合优化方法。该方法能够根据市场的实时变化自动调整投资组合优化模型, 通过内部和外部资产池的动态交易, 及时优化资产构成与配置。其次, 马宇红等人指出, 投资者在决策中往往希望持有高回报且低风险的投资组合。然而, 这种需求存在矛盾, 因为高回报通常伴随高风险, 而降低风险又会减少潜在回报。因此, 理想的投资配置应在风险与回报之间寻求平衡。为此, 他们将回报和风险合并为一个综合指标——收益风险评判准则, 并运用量子进化算法进行优化[13]。

然而, 通过对相关文献的审查, 发现现有研究存在一些不足。尽管智能投资组合优化逐渐受到关注, 许多研究仍忽视投资过程中的风险因素, 通常将回报率和累积回报率最大化作为优化目标。这些净收入指标未能充分反映金融交易中的回撤情况。因此, 将风险约束纳入投资组合优化显得尤为重要, 以帮助投资者更有效地应对市场风格的变化。

3. 研究方法和模型构建

3.1. 智能优化算法

3.1.1. 遗传算法

遗传算法(Genetic Algorithm, GA)是一种受自然进化启发的优化算法, 通常适用于搜索以及优化问题。它模拟了生物进化中的遗传和适应性优化过程, 通过模拟遗传操作来搜索最优解或近似最优解。

(1) 基本原理:

① 个体表示: 将问题的解表示为染色体(Chromosome), 通常是一个由二进制串、整数、浮点数等构成的数据结构。

② 初始化种群: 随机生成初始群体(Population)中的个体, 每个个体都是一个可能的解。

③ 适应度评估：对每个个体计算其适应度(Fitness)，即解决方案优劣的度量标准。适应度函数通常与问题的特性紧密相关。

④ 选择操作：根据每个个体的适应度选择父代个体用于产生后代。适应度高的个体被选择的概率较大，以促进优良基因的传播。

⑤ 遗传操作：

- 交叉(Crossover)：模拟生物界的基因重组，选中的个体进行交叉操作，生成新的后代个体。

- 变异(Mutation)：对新生成的染色体进行随机的变异操作，以增加种群的多样性和探索新解空间的能力。

⑥ 生成新种群：通过选择和遗传操作生成新一代种群。

⑦ 终止条件：当达到设定的终止条件(如达到最大迭代次数、找到满意的解等)时停止算法运行，否则返回步骤(4)继续迭代。

(2) 应用和优点：

① 适用范围：适用于多种复杂优化问题，如旅行商问题、参数优化、工程设计、调度问题等。

② 并行性：算法的并行性较强，易于在分布式系统上实现和优化。

③ 全局搜索：能够在大范围的解空间内进行全局搜索，有助于找到较优解。

④ 非导数优化：与传统的基于梯度的优化方法相比，遗传算法无需求解导数信息，因此更适用于非光滑、非线性、高度复杂的问题。

(3) 小结：

遗传算法是一种强大的优化技术，尤其适用于复杂、非线性和多模态的问题。它通过模拟生物进化的过程，在解空间中寻找最优或接近最优的解。然而，算法的性能高度依赖于参数的选择、适应度函数的设计和种群的初始化策略，需要在实际应用中进行调优和验证。

3.1.2. 粒子群算法

粒子群算法(PSO)是一种基于群体智能的优化算法，其灵感来自于对鸟群或鱼群等生物群体协同行为的模拟。通过模拟个体在解空间中的位置和速度变化，可以找到最优解或近似最优解。

(1) 基本原理：

① 个体表示：在 PSO 中，每个个体(粒子)在解空间中代表一个潜在的解。通常用一个位置向量来表示。

② 初始化：随机初始化一群粒子，每个粒子的初始位置和速度可以在解空间内随机选取。

③ 适应度评估：对每个粒子计算其适应度(Fitness)，即解决方案的质量度量。

④ 更新个体最佳位置(pBest)：对每个粒子而言，记录其历史上找到的最佳位置及其对应的适应度值。

⑤ 更新全局最佳位置(gBest)：在整个群体中找出历史上最优的粒子位置和对应的适应度值，作为全局最优解。

⑥ 更新速度和位置：

- 速度更新：根据当前速度、个体最佳位置和全局最佳位置，调整粒子的速度，以寻找更优的位置。

- 位置更新：根据更新后的速度，更新粒子的位置。

⑦ 迭代优化：重复更新每个粒子的速度和位置，直到满足停止条件。

(2) 应用和优点：

① 适用范围：PSO 广泛用于连续优化问题，如函数优化、神经网络训练、参数优化等。

② 简单实现：算法相对简单，易于理解和实现。

③ 全局搜索能力：PSO 能够在解空间内进行全局搜索，找到较优解，并且能够避免陷入局部最优解。

④ 并行性: PSO 算法天然适合并行化处理,可以有效利用多核处理器或分布式计算资源。

(3) 小结:

粒子群算法是一种有效的优化方法,通过模拟群体中个体的协同行为,以期望寻找到最优解或接近最优解。然而,PSO 也有其局限性,如对参数的敏感性、易陷入局部最优等问题,需要在应用中进行适当的参数调优和策略设计。

3.1.3. 蚁群算法

蚁群算法(ACO)是一种启发式优化算法,最初由 Marco Dorigo 等人提出。它利用蚁群在寻找食物过程中的群体智能行为来解决组合优化问题。

(1) 基本原理:

① 蚁群行为模拟:蚁群在寻找食物时,通过释放信息素来标记路径,并通过信息素浓度选择路径。ACO 算法模拟了这一过程。

② 问题建模:将优化问题转化为图的形式,其中节点表示问题的解空间中的点,边表示可能的移动路径或解之间的转换。

③ 信息素初始化:将所有路径上的信息素浓度初始化为一个较小的正数。

初始时,信息素浓度可以是随机的或者根据问题的特定知识设置。

④ 蚂蚁的路径选择:每只蚂蚁根据一定的概率规则选择下一步的路径,直到找到一条完整的解。

⑤ 信息素更新:通常是通过增加经过的路径上的信息素浓度,以及在每次迭代后衰减信息素浓度来实现。

⑥ 全局信息素更新:在每次迭代结束后,根据蚂蚁的反馈信息和信息素的挥发,更新全局的信息素浓度,以增强优化过程的全局搜索能力。

⑦ 迭代优化:重复执行蚁群的路径选择、信息素更新等步骤,直到达到预定的迭代次数或满足终止条件为止。

(2) 应用和优点:

① 适用范围:适用于多种组合优化问题,如旅行商问题、调度问题、路径规划等。

② 全局搜索:ACO 能够在解空间中进行全局搜索,并能够逐步收敛到最优解或者接近最优解。

③ 并行性:蚁群算法易于并行化处理,因为每只蚂蚁可以独立地探索解空间。

④ 自适应性:算法具有自适应性,能够自动调整路径选择概率和信息素浓度,以更好地探索解空间。

(3) 小结:

蚁群算法是一种基于概率和启发式的优化算法,利用蚁群在寻找食物过程中的集体智能行为来解决复杂的组合优化问题。尽管算法具有许多优点,如全局搜索能力和适应性,但也需要考虑参数的选择、信息素的更新策略等因素,以提高算法的效率和收敛性。

3.1.4. 模拟退火算法

模拟退火算法(SA)是一种启发式全局优化算法,其灵感来源于固体退火过程中的物理现象,它是由 Kirkpatrick 等人于 1983 年提出。它通过模拟金属物体在高温下慢慢冷却过程中的结晶过程,进而寻找复杂问题的最优解或接近最优解。

(1) 基本原理

① 状态空间建模:将优化问题的解空间视为状态空间,每个状态对应一个可能的解。

② 能量函数定义:定义一个能量函数或成本函数,用于评估每个状态的优劣程度。目标是最小化能量函数的值。

③ 初始解的生成：随机生成初始解作为起始点。

④ 温度参数设定：设定初始温度(T)和冷却率(α)，温度表示系统的随机性程度，温度高时接受较差的解的概率较大。

⑤ 状态转移：在当前温度下，通过一定的转移规则(如邻域搜索)，生成新的状态(新解)。

⑥ 接受准则：根据 Metropolis 准则，决定是否接受新状态：

如果新状态比当前状态更优，则接受新状态。

如果新状态比当前状态差，根据一定的概率接受新状态，这个概率与温度相关，随着温度的降低而减小。

⑦ 温度更新：根据设定的冷却率，降低温度，即降低接受较差解的概率，逐步过渡到更保守的搜索策略。

⑧ 迭代优化：重复执行状态转移、接受准则和温度更新，直到达到终止条件(如达到最大迭代次数或温度降低到设定的最低温度)。

(2) 应用和优点：

① 全局搜索能力：SA 能够在解空间内进行全局搜索，有助于找到较优解或接近最优解。

② 适用范围：适用于连续优化问题和离散优化问题，如旅行商问题、参数优化、布局设计等。

③ 自适应性：SA 具有一定的自适应性，能够通过调整温度和接受概率来探索解空间，并在搜索过程中逐渐降低搜索的随机性。

简单实现：算法相对简单，易于理解和实现。

(3) 小结：

模拟退火算法是一种经典的全局优化算法，通过模拟物理中的退火过程，利用温度参数控制搜索的随机性，以达到在复杂问题中找到较优解的目的。尽管算法需要适当的参数调优和设计，但在实践中已经被广泛应用于各种优化问题，并取得了许多成功的应用案例。

3.2. 风险约束模型

3.2.1. 目标函数

目标函数的不同会影响智能体学习的决策，进一步导致不同的投资组合优化结果。在现有的大部分关于投资组合优化研究中，目标函数基本上都是投资组合的收益，缺少风险因素考虑进去的研究。然而，要想获得更多的收益，不可避免会产生一定的风险，因此，将风险因素的约束条件融入投资组合管理过程中是特别有必要的，它可以满足各类投资者的不同投资需求。本研究选取了夏普比率，这是一个比较常见且具有代表性的综合回报和风险指标。

夏普比率是一个既考虑收益又考虑风险的综合指标，它代表的是单位风险收益，主要用来衡量投资的稳健性。夏普比率也用来处理正向投资组合价值，这意味着，它将上涨和下跌的波动率视为一个同等位置。

$$\text{Sharpe} = [E(r_p) - r_f] / \sigma_p$$

假设投资 N 种资产，第 i 种资产的预期收益率为 $E(r_i)$ ，投资组合预期收益率为 $E(r_p)$ ，无风险利率为 r_f ，投资组合标准差为 σ_p ， w_i 为第 i 种资产的投资比重。

3.2.2. 投资组合约束条件

(1) 投资比例和为 1， $\sum_{i=1}^N w_i = 1$ ；

(2) 不允许卖空，即 $w_i \in [0,1]$ 。

假设投资 N 种资产，第 i 种资产的预期收益率为 $E(r_i)$ ，投资组合预期收益率为 $E(r_p)$ ，无风险利率为 r_f ，投资组合标准差为 σ_p ， w_i 为第 i 种资产的投资比重。

综上所述，本文构建的模型为：

$$\begin{aligned} \max S &= [E(r_p) - r_f] / \sigma_p \\ \text{s.t.} \quad &\begin{cases} \sum_{i=1}^N w_i = 1 \\ w_i \in [0,1] \end{cases} \end{aligned}$$

4. 实证分析

4.1. 数据收集与处理

通过 python 获取上证 50 成分股 2023 年 1 月 1 日至 2024 年 1 月 1 日一个交易年的日度数据，以此为研究对象，其中无风险利率选取 2023 年 12 月 31 日 10 年期中国国债收益率，如表 1。所选用的样本数据包括股票的开盘价、收盘价、最高价、最低交易量。

Table 1. Chinese Government Bond Yield Curve (maturity) December 31, 2023

表 1. 中国国债收益率曲线(到期)2023 年 12 月 31 日

名称	标准期限(年)	收益率(%)
中债国债收益率曲线(到期)	0	1.4508
中债国债收益率曲线(到期)	0.08	1.5976
中债国债收益率曲线(到期)	0.17	1.801
中债国债收益率曲线(到期)	0.25	1.8017
中债国债收益率曲线(到期)	0.5	2.06
中债国债收益率曲线(到期)	0.75	2.0208
中债国债收益率曲线(到期)	1	2.0796
中债国债收益率曲线(到期)	2	2.2098
中债国债收益率曲线(到期)	3	2.2894
中债国债收益率曲线(到期)	5	2.4001
中债国债收益率曲线(到期)	7	2.5328
中债国债收益率曲线(到期)	10	2.5553
中债国债收益率曲线(到期)	15	2.6806
中债国债收益率曲线(到期)	20	2.7349
中债国债收益率曲线(到期)	30	2.8269
中债国债收益率曲线(到期)	40	2.9047
中债国债收益率曲线(到期)	50	2.9125

4.2. 投资组合优化的绩效结果对比

如表 2，用遗传算法进行投资组合优化，其对应的最大夏普比约为 1.119，粒子群算法对应的最大夏

普比约为 1.623, 蚁群算法对应的最大夏普比约为 3.711226, 模拟退火算法对应的最大夏普比为 3.711224。相比之下, 粒子群算法和模拟退火算法更适用于本文, 二者进行投资优化的结果不相上下, 相差甚小, 其中蚁群算法计算出的最大夏普比模拟退火算法的略高一点。

Table 2. Portfolio weight allocation and maximum sharpe ratio of each algorithm
表 2. 各算法投资组合权重分配及最大夏普比

股票代码	遗传算法	粒子群算法	蚁群算法	模拟退火算法
600519.SH	0.02541809	0	5.67800375e-14	0
601318.SH	0.00432377	0.11804879	1.83211127e-14	0
600036.SH	0.00134945	0	1.08496550e-14	0
601899.SH	0.00433296	0	4.64769045e-02	0.0466
600900.SH	0.17785807	0	2.34032928e-02	0.0234
601166.SH	0.0050044	0	3.36363844e-14	0
600276.SH	0.01529822	0	4.41631729e-02	0.0441
600030.SH	0.01140522	0.02577353	6.89795575e-03	0.0069
601398.SH	0.0203029	0.151453	2.30034587e-02	0.0229
600887.SH	0.02464928	0	2.30268105e-14	0
600309.SH	0.00991531	0	1.39843498e-14	0
601288.SH	0.00771914	0.15792976	5.42950488e-02	0.0542
601088.SH	0.01459205	0	2.68707223e-02	0.0269
600028.SH	0.01562313	0	5.94241507e-02	0.0594
600809.SH	0.00413683	0	1.88706193e-14	0
601012.SH	0.01375873	0	5.98077701e-14	0
601857.SH	0.00151953	0	8.82567091e-02	0.0883
601668.SH	0.01524106	0	2.79778380e-14	0
600406.SH	0.01521471	0	3.31976857e-14	0
601225.SH	0.01028628	0	2.98388051e-02	0.0298
603259.SH	0.01638318	0	4.00087588e-14	0
600690.SH	0.00423228	0	2.36060114e-14	0
601728.SH	0.00623192	0.00947532	6.69304630e-02	0.067
601988.SH	0.01048809	0	5.68877694e-02	0.0568
600050.SH	0.03421252	0	4.05684331e-14	0
600031.SH	0.01589395	0.17520808	2.74547681e-14	0
688981.SH	0.02859272	0	7.01778032e-02	0.0702
601888.SH	0.01959067	0	1.21208757e-13	0
600150.SH	0.02922266	0	6.90452155e-02	0.069
601601.SH	0.02417341	0.17863996	7.69114589e-03	0.0076
600089.SH	0.00859192	0	1.66368385e-14	0

续表

601390.SH	0.01381769	0	1.12113843e-02	0.0112
688041.SH	0.17524217	0	1.70521609e-01	0.1707
603501.SH	0.02983287	0.16766483	8.59918129e-02	0.086
600104.SH	0.04431583	0	4.04149402e-14	0
600436.SH	0.01636406	0	1.99143659e-14	0
688111.SH	0.00845816	0	5.89125760e-02	0.059
600438.SH	0.0019387	0	3.16908561e-14	0
600905.SH	0.00507417	0	1.16639799e-14	0
601919.SH	0.00581666	0	4.24040744e-14	0
603288.SH	0.01475147	0	8.12233440e-14	0
600048.SH	0.01668018	0	3.40535316e-14	0
600111.SH	0.02192968	0	7.38112328e-15	0
603986.SH	0.00938293	0	4.44624250e-14	0
601628.SH	0.00492138	0	2.20619945e-15	0
600893.SH	0.0016863	0	2.05292062e-14	0
601669.SH	0.0228717	0.01580672	2.33586895e-14	0
603799.SH	0.00319271	0	4.76359142e-14	0
601633.SH	0.0047143	0	3.30065142e-14	0
688599.SH	0.00344659	0	9.83342292e-14	0
最大夏普比	1.1190465133984193	1.6228736383953568	3.7112257231344676	3.711224

5. 结论与建议

5.1. 研究结论

在对复杂投资组合优化的研究中，各种算法展现出不同的优势，尤其是蚁群算法表现突出。通过模拟蚂蚁寻找食物的行为，蚁群算法能够在大规模搜索空间中有效找到高质量的投资组合配置，并灵活处理复杂的约束条件。本文设计了一系列量化实验，选取了上证 50 成分股在 2023 年 1 月 1 日至 2024 年 1 月 1 日的多行业股票数据，包括科技、金融、医疗和消费品，确保了数据的多样性和代表性。本文对蚁群算法、遗传算法、粒子群优化算法和模拟退火算法进行了比较，这些算法分别代表了不同的优化思路和策略，能够为研究提供多角度的视野。在评价指标方面，主要使用日度收益率、风险(以标准差表示)、和夏普比率，这些指标有效反映了各算法在收益、风险控制等方面的表现，实验结果显示，蚁群算法的夏普比率达到 3.71226，显著高于其他算法，表明其在风险调整后收益方面表现更佳，这进一步证明了其在不确定市场环境下的有效性。

综上所述，量化分析表明蚁群算法在复杂投资组合优化中具有显著优势，其独特的搜索机制能有效探索解空间，找到高质量的投资配置。未来研究可结合其他智能优化算法，如遗传算法，以提升优化性能，并考虑不同市场环境下的动态调整机制，通过实时监测市场变化适时调整投资组合，从而增强投资的稳健性。总体而言，蚁群算法在投资组合优化中表现出色，未来的研究将验证其实际应用潜力，为投资者提供更科学的决策支持。

5.2. 建议

首先，在稳定市场环境下，建议投资者采用保守的投资策略，并实施严格的风险控制措施。这将确保投资组合的稳健性并支持可持续的长期表现。通过选择低波动性资产和分散投资，投资者可以降低风险，同时获得稳定的收益，从而更好地应对市场的不确定性。

其次，对于波动性较高的市场，建议在蚁群算法的基础上引入动态调整机制。这可以包括灵活更新算法参数、实时结合市场数据进行调整，以便快速响应市场变化并最大化投资回报。例如，随着市场情绪或经济指标的变化，投资组合的权重和策略可以相应进行优化，以捕捉短期机会和减少潜在损失。

同时，考虑到不同投资者的风险偏好和目标，建议定制化算法参数。这可以通过根据投资者的投资时间段、收益目标和风险容忍度来调整算法的优化目标和约束条件，以实现个性化的投资组合配置。

最后，鼓励金融机构和投资者在投资组合管理中采用先进的优化技术，并持续关注和应用最新的算法进展。此外，未来的研究可以进一步探索如何结合人工智能和大数据分析，以提升投资决策的精确度和效率。

参考文献

- [1] 王舞宁, 章宁, 范丹, 王熙. 基于动态交易和风险约束的智能投资组合优化[J]. 中央财经大学学报, 2021(9): 32-47.
- [2] Yunusoglu, M.G. and Selim, H. (2013) A Fuzzy Rule Based Expert System for Stock Evaluation and Portfolio Construction: An Application to Istanbul Stock Exchange. *Expert Systems with Applications*, **40**, 908-920. <https://doi.org/10.1016/j.eswa.2012.05.047>
- [3] Paiva, F.D., Cardoso, R.T.N., Hanaoka, G.P. and Duarte, W.M. (2019) Decision-Making for Financial Trading: A Fusion Approach of Machine Learning and Portfolio Selection. *Expert Systems with Applications*, **115**, 635-655. <https://doi.org/10.1016/j.eswa.2018.08.003>
- [4] 齐岳, 林龙, 王治皓. 大数据背景下遗传算法在投资组合优化中的效果研究[J]. 中国管理科学, 2015(S1): 464-469.
- [5] 吴婉婷, 朱燕, 黄定江. 在线投资组合选择的半指数梯度策略及实证分析[J]. 计算机应用, 2019(8): 2462-2467.
- [6] Freitas, F.D., De Souza, A.F. and de Almeida, A.R. (2009) Prediction-Based Portfolio Optimization Model Using Neural Networks. *Neurocomputing*, **72**, 2155-2170. <https://doi.org/10.1016/j.neucom.2008.08.019>
- [7] 薛雨石. 遗传算法在投资组合优化中的应用[J]. 合作经济与科技, 2023(20): 54-56.
- [8] 周新, 赵明君. 人工智能背景下投资组合优化问题研究[J]. 常州工学院学报, 2019, 32(2): 31-35.
- [9] 陈霞. 智能优化算法在证券投资组合应用研究[D]: [硕士学位论文]. 郑州: 华北水利水电大学, 2020.
- [10] 张波, 陈睿君, 璐璐. 粒子群算法在投资组合中的应用[J]. 系统工程, 2007(8): 108-110.
- [11] 吴昊, 魏文红, 张宇辉. 基于改进粒子群优化算法的投资组合优化研究[J]. 东苑理工学报, 2023, 30(3): 32-40.
- [12] 于延磊. 基于改进蚁群算法的投资组合优化研究[D]: [硕士学位论文]. 天津: 天津商业大学, 2017.
- [13] 马宇红, 孙亚娜, 李兴义. 具有有限额约束的投资组合优化问题的量子进化算法[J]. 西北师范大学学报, 2022, 58(2): 25-33.